



TOKYO METROPOLITAN UNIVERSITY

首都大学東京

2019 年度修士論文

ニューラルネットワークを用いた
複合機の回収量予測に関する研究

指導教員 開沼 泰隆

首都大学東京大学院
システムデザイン研究科
電子情報システム工学域

18861623 佐藤 大輔

目次

第1章	序論	1
1.1	はじめに	1
1.2	研究背景	1
1.3	研究目的	1
1.4	本論文の構成	2
第2章	クローズド・ループ・サプライ・チェーン	4
2.1	はじめに	4
2.2	サプライ・チェーン・マネジメント	4
2.3	クローズド・ループ・サプライ・チェーン	9
2.4	おわりに	15
第3章	需要予測	16
3.1	はじめに	16
3.2	統計的な需要予測モデル	16
3.3	ニューラルネットワークによる需要予測モデル	17
3.4	おわりに	24
第4章	方法論	25
4.1	はじめに	25
4.2	提案手法	28
4.3	学習データの選定	29
4.4	入力ユニット数と中間ユニット数の決定	36
4.5	おわりに	42

第5章 結果と考察 43

5.1	はじめに	43
5.2	学習データとテストデータ	43
5.3	評価指標	43
5.4	提案方法の結果	44
5.5	提案方法の考察	51
5.6	各入力モデルによる結果比較	52
5.7	おわりに	59

第6章 結論 60

謝辞 61

参考文献 62

第1章 序論

1.1 はじめに

近年、サプライ・チェーン・マネジメントと呼ばれる各種の方法論や事例について極めて大きな関心をもたれている。従来の日本は製品を大量に製造し、それを消費者が消費するという、いわゆる大量生産・大量消費型の社会であった。しかし、バブルの崩壊とともに、消費者のニーズが多用していったことで市場の成熟化が進み、企業は今までとは異なる新たな生産体系を構築することが求められた。

一方で、多くの製品は設計・製造する段階で環境への配慮が足りないまま生産され、その製品寿命が終えると必然的に大量に廃棄されることとなる。その結果、地球温暖化問題や資源枯渇問題など我々の生活を脅かす社会的問題となっている。

そのため、企業では環境問題に対する意識が高まり社会的責任という観点から、環境問題への取り組みが評価されるようになった。この問題を解決するために廃棄される製品を回収して新しい製品の生産に活用するといった循環型生産システムの確立が望まれている。そのため、従来のフォワード・サプライ・チェーンに加え、リユース、リサイクルを考慮したリバース・サプライ・チェーンをもつクローズド・ループ・サプライ・チェーンに注目を集めている。

1.2 研究背景

先に述べたように持続可能な循環型社会の構築に向けて、企業の生産活動において、資源・エネルギー消費や廃棄物の削減に努めるなど環境問題への対策に取り組むことが要求されている。その中で、製造業では使用済みの製品を顧客が廃棄物として処分するのではなく、企業が再製造のために回収するという形で環境問題に取り組む例が増えてきている。このシステムを機能させるために重要になるのがクローズド・ループ・サプライ・チェーンである。この中の一つであるリマニュファクチャリングは、その資源消費や廃棄物の削減に大きな役割を果たすとされており、近年では主に複写機を取扱う製造業などで取り入れられている。

1.3 研究目的

前節で述べたように複合機メーカーである（株）リコーでは、使用済み製品や部品を用いることで資源消費や廃棄物の削減に取り組んでいる。製品に組み込まれている部品は使用后、新しい部品と交換される。このとき重要なこととして部品の交換台数と交換時期があり、これらを予測することがその後の生産計画を立てるために必要不可欠である。交換台数の予測というのは使用済み部品の回収量の予測と同時に、新たな部品の生産量の予測も可能とする。

もし、生産過剰となれば過剰在庫を生み、在庫廃棄率を高める。生産過少となれば、店頭在庫不足による機会損失を発生させる。そのため、多くの企業では製品の過剰在庫や販売の機会損失を少なくするために柔軟で素早い生産計画を立案するための需要予測が求められてきている。

そのため、本研究では、部品回収（交換）予測にニューラルネットワークを用いて、過去に販売された類似製品の部品交換データを学習させることで、最新製品における部品交換データが少ない場合でも、次年度の部品交換量の予測方法を提案することを目的としている。

1.4 本論文の構成

本論文の構成及び対応関係を図 1.1 に表す。第 2 章ではサプライ・チェーン・マネジメントの概要と成功企業の事例、および課題について述べ、循環型社会構築に期待されるクローズド・ループ・サプライ・チェーンの概要、企業事例について述べる。第 3 章では需要予測方法について述べる。従来の統計的手法とニューラルネットワークを用いた予測方法の概要、学習の問題点と効率化について述べる。第 4 章では、本研究の方法について述べる。提案手法のニューラルネットワークモデルについて学習データとテストデータについて述べる。第 5 章では、第 4 章で述べたモデルを用いて機種を増やして予測・考察を行う。第 6 章では結論と課題を述べる。

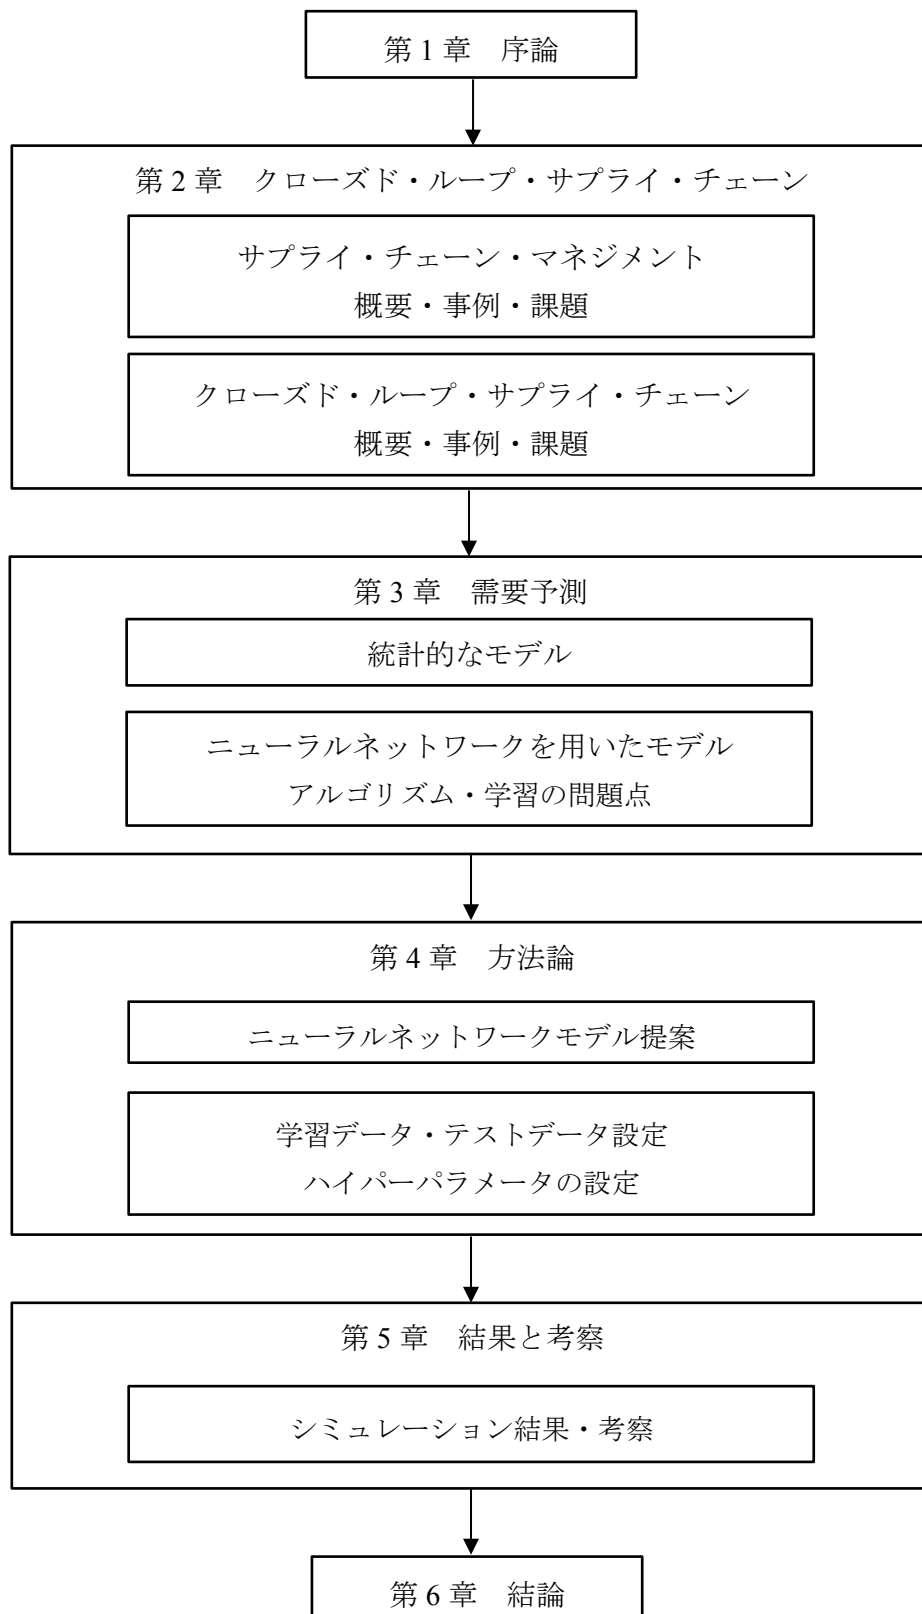


図 1.1 本論文の構成

第2章 クローズド・ループ・サプライ・チェーン

2.1 はじめに

現在、サプライ・チェーン・マネジメントは企業から大きな関心を持たれている。本章では、サプライ・チェーン・マネジメントの概要についてまとめるとともに、実際に取り入れている企業の事例、およびサプライ・チェーン・マネジメントにおける課題について述べる。その後、社会の環境に対する意識の変化と、循環型社会について述べるとともに、クローズド・ループ・サプライ・チェーンの概要、課題について述べる。

2.2 サプライ・チェーン・マネジメント

近年、サプライ・チェーン・マネジメントとよばれる概念に大きな関心が抱かれている。多くの企業がその戦略、手法を取り入れているがサプライ・チェーン・マネジメントに関心を寄せている背景の一つとして、市場の変化が挙げられる。

従来の日本では、消費者が求める製品の種類は少なく市場の変化スピードは現在と比べて遅かったため、何を売ればよいか、何を作ればよいかを予測することは容易であった。製造業内のそれぞれの部門で考えると、生産部門は生産効率を求め大ロット生産を行い、仕掛在庫を増加させた。物流部門は輸送コストを抑えるため、一度に大量の輸送を行う大ロット輸送により流通在庫を増加させた。販売部門は、品切れによる機会損失は多大な損失と考え、欠品率を最小にするために在庫を増加させた。この時代は、作れば売れる時代であったため、一時的に在庫をもったとしてもいつかは売れて利益につながる事ができた。そのため、部門ごとに状況を把握せずとも在庫を持つことに大きな問題はなかった。これが、大量生産・大量消費につながっている。しかし、1970～80年代ごろから供給能力が過剰傾向となって顧客の立場が強くなり、顧客の望む製品やサービスをいかにタイムリーに提供するかが求められる消費者主導の経済への移行が始まった[1]。そしてバブル崩壊とともに市場の成熟化が進み、消費者の多様化と呼ばれる傾向が強くなった。消費者の好みは個人によって異なり、消費者が購入するブランドや品目数は増加し、使用期間の短縮化が進んでいる[2]。

このように生産者主導の経済から、消費者主導の経済へと移行した市場構造の本質的な変化が起きた。こうした消費の多様化に対応するために企業間の戦略的提携が必要となってきた。さらに、グローバル化の発展、企業間競争の激化、情報通信技術の進展などを背景に、サプライ・チェーン・マネジメントに関心が寄せられるようになった。

サプライ・チェーン・マネジメントは生産管理、物流管理、マーケティング管理といった幅広い専門分野において研究が進められている。圓川ら[3]によると、サプライ・チェーンという言葉は自動車産業におけるサプライヤーである部品メーカーと組立メーカーの長期的関係のもとでの、部品供給の連鎖や新製品開発活動のオーバーラップに

ついて、系列批判の一方でその組織連携・学習モデルの強みを米国がベンチマークすることによって生まれたものである。サプライ・チェーン・マネジメントの定義は様々あり、論者によって異なる。

例えば、日本工業規格 JIS Z 814[4]には、「サプライ・チェーン・マネジメントは資材供給から生産、流通、販売に至る物又はサービスの供給連鎖をネットワークで結び、販売情報、需要情報などの部門間又は企業間でリアルタイムに供給することによって、経營業務全体のスピード及び効率を高めながら顧客満足を実現する経営コンセプト」と定義されている。

徳山ら[1]は、サプライ・チェーンとは、「原材料の調達、部品の加工、製品の組立て、倉庫や配送センターでの保管や仕分け、そして小売りを経て最終顧客に至る全てのモノの流れを、各企業や事業体の活動なりとして、すなわち「供給連鎖」として捉える考え方」と定義している。

サプライ・チェーン・カウンスル日本支部では[2]、サプライ・チェーン・マネジメントとは、「価値提供活動の初めから終わりまで、つまり原材料の供給者から最終需要者に至る全過程の個々の業務プロセスを、一つのビジネスプロセスとして捉えなおし、企業や組織の壁を越えてプロセスの全体最適化を継続的に行い、製品・サービスの顧客付加価値を高め、企業に高収益をももたらす戦略的な経営管理手法である」と定義している。

サプライ・チェーン・マネジメント専門家協会（Council of Supply Chain Management Professionals: CSCMP）[5]は、「サプライ・チェーン・マネジメントは、調達と購買、組立加工とロジスティクス活動にかかわる計画と管理を含む。サプライヤー、中間業者、サードパーティープロバイダーと顧客であるチャネルパートナーとの協調と協議を含む。本質的には、サプライ・チェーン・マネジメントは、企業内、企業間の需要管理と供給管理を統合することである。」と定義している。

森田[6]は、サプライ・チェーンとは、「企業や製品やサービスを顧客に供給するために必要な様々な活動がつながっている状態を指すことであり、サプライ・チェーン・マネジメントはそのチェーン・システムを設計し、作り上げ、システムの稼働を計画し、稼働状況を管理すること」と定義している。

Mentzer ら[7]は、戦略的な脈絡（統合サプライ・チェーン・マネジメントによる顧客価値と顧客満足の実現）で効率性（コスト削減）及び効果性（顧客サービス）を実現し、最終的に収益性をもたらし競争優位性を創出することにある。

これらのことから、サプライ・チェーン・マネジメントの主要な目的は、サプライ・チェーンの川上に位置する原材料メーカーから、川下の販売業者までの一連の活動を統合し、コスト削減、顧客価値と顧客満足の向上、競争優位性の確保を図りサプライ・チェーンの効率的な流れを実現することであるといえる。図 2.1 にサプライ・チェーン・マネジメントの概略を示す。

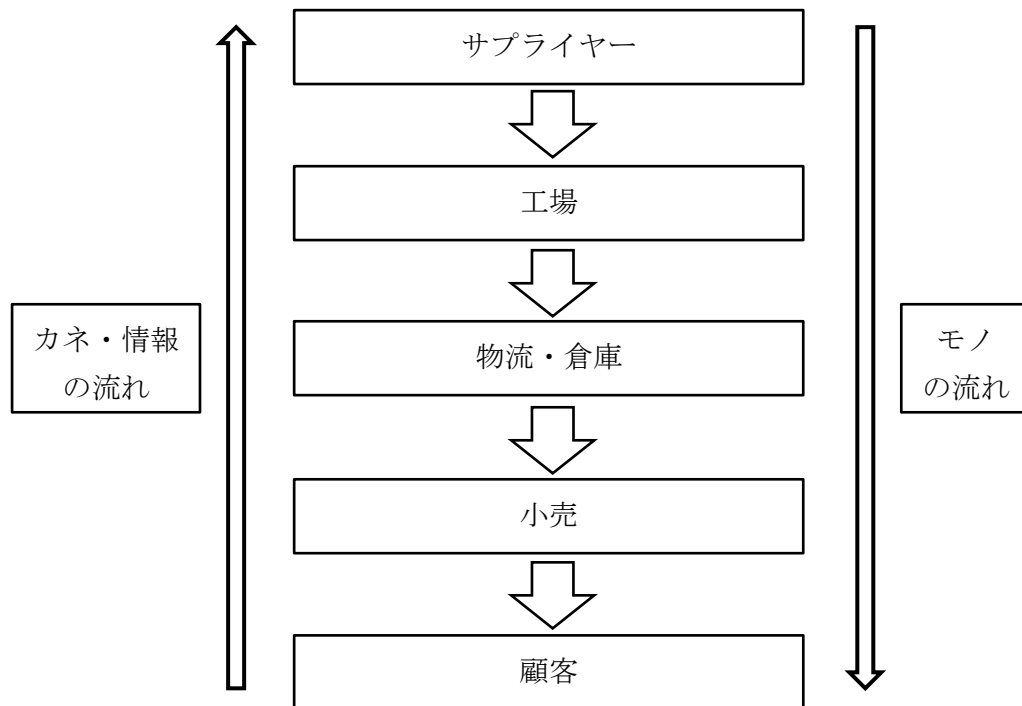


図 2.1 サプライ・チェーン・モデル
※[1]を基に加筆・修正

2.2.1 サプライ・チェーン・マネジメントの事例

本節では企業におけるサプライ・チェーン・マネジメントの導入事例として以下の三社を紹介し、そのビジネス・モデルについて述べる。

(1) トヨタ自動車株式会社[8]

自動車のような数多くの部品から作られる製品は、部品の調達やリードタイムなど、緻密な生産計画を立てる必要がある。そこで、トヨタ自動車では、ジャスト・イン・タイム (Just In Time :JIT) という生産方式を行うことで、リードタイムを徹底的に管理して、在庫、リードタイム、補充、品質などのムダを排除している。JIT とは、必要なものを、必要な時に、必要なだけ供給することで、ムダ、ムラ、ムリをなくし、生産効率を向上させる戦略である。

JIT の推進手段であるマネジメント活動には、短納期生産、段取り時間の最小化、ロットサイズの縮小化、待ち時間の最小化、リードタイムの短縮化、品質改善やサプライヤーとのパートナーシップ化などがあり、これらの活動を通して、トヨタ自動車は現在世界トップの自動車メーカーになった。

(2)P&G(プロクター・アンド・ギャンブル)[8]

P&G は、大きな食料品日曜雑貨店と量販店に対して在庫を管理している。P&G の顧客サービス担当者は、日々の基本的な商品補充を、商品の動きや在庫と短期予測をベースにして、小売物流センターでの商品の動きを監視するために CRP(Continuous Replenishment Program)を活用している。これは、従来の小売店が各種情報や経済性に基づいた発注から、需要予測を加味した商品補充へと商品補充プロセスを変革するものである。このシステムの導入により、顧客サービス担当者は販売促進のための補充よりもさらに正確に予測するために、小売店と密接な協力関係を維持することが出来ている。

(3)ザラ株式会社[9]

アパレル商品は、商品の企画・開発から店頭に出るまでに長い時間を要することが一般的である。そのため、過剰在庫や在庫切れといった需要の不確実性によって悩まされる商品の一つとされてきた。ザラ株式会社は、商品開発から原料調達、生産、流通、販売までのサプライ・チェーンのすべてのプロセスを自らコントロールする垂直統合型生産を行うことで、新商品を頻繁に少量ずつ製造し、すばやく店舗に納品するというビジネス・モデルをつくりあげた。

ザラ社のビジネスシステムは、常に一定のリズムを保つことで、サプライ・チェーンを管理し、サプライ・チェーンの各プロセスではなく全体を最適化することで大きな効力を発揮している。

2.2.2 サプライ・チェーン・マネジメントの課題

Lee[10]は、高いパフォーマンスを誇るサプライ・チェーンの性能として、迅速さ(Agile)、適応性(Adaptable)、連携(Align)の3つをあげている。需要や供給への急激な変動に適応する迅速さ、市場構造の変化に長期的に対応する適応性、さらに自社の収益を上げるためにサプライ・ネットワーク内すべての企業のインセンティブ体系を整える必要がある。迅速さ、適応性、連携を備えたサプライ・チェーンは持続可能な競争優位性を企業にもたらしることが出来る。これらの条件を軽視し、少しの無駄を許容することを恐れ、効率性のみの追及に偏りすぎることによって需要や供給の予期せぬ変化に対応することが出来ないと指摘している。また、適応性は同じ業種、業態であっても企業あるいはサプライ・チェーンを取り巻く環境は常に変化していることから、サプライ・チェーン・マネジメントに完成形は、環境変化に合わせて適応していく必要がある。

このように完璧なサプライ・チェーンを実現することは非常に困難である。ここからはサプライ・チェーン・マネジメントの代表的な課題について紹介する。

(1) 需要の不確実性[8]

サプライ・チェーン・マネジメントを行う際、需要を正確に予測することは重要である。しかし、近年の商品サイクル短縮化により、市場動向の予測が非常に困難になって

きている。特に、消費財の場合にはサイズや色などの商品属性が多岐にわたるため、それぞれについて売れ行きを分析する必要があるため、需要を予測することは難しい。

(2) 鞭の効果(Bullwhip Effect)[11]

鞭の効果とは、サプライ・チェーンにおいて需要情報が川下から川上へと伝達される際に多段階の意思決定などにより、需要量の情報が大きく変動してしまうことである。その発注量(需要量)の変化増幅が鞭をならしているさまに似ていることから鞭の効果と呼ばれる。

鞭の効果が起こる原因として、需要予測の更新、一括注文、価格変動、配給と品切れの4つが考えられる。この4つの原因は互いに影響し、調整するため相互に依存している。鞭の効果を軽減するための一番効率的な方法は意思決定段階を減らすことである。しかし現実的に段階を減らすことは簡単ではないため、需要などの情報を共有することで全体最適に近づけることも考えられる。また、価格の安定化、企業間の在庫管理、輸配送政策のコーディネーションも効果的である。

(3) 顧客許容リードタイムと比較したスループットの長さ

材料を調達してから生産し、消費者に届けるまでの時間(スループットタイム)が、顧客許容リードタイム(顧客が購入の意思決定を行い、発注してから納品までの許容できる時間)より短ければ、需要を受けてから生産をすることができ、顧客の需要の変化に対応することが出来る。しかし、実際はこのようなケースは少ない。例としてアパレル業界のような商品の売れるシーズンが極めて短い場合では、受注生産は困難であるため、需要予測に基づく見込み生産を行わなければならない。その結果、在庫切れによる機会損失や、不良在庫を抱える原因となってしまう。また、グローバル化によってリードタイムが長くなり、輸送リードタイムの不確実性が増していることも原因の一つである。

(4) ダブル・マージナリゼーション[12]

ダブル・マージナリゼーション(二重限界化)とは、サプライ・チェーンの各企業が、自分の利益を多く出すために価格を高くつけ合うことで、最終価格が高騰し需要を減らしてしまい各企業の利益が減少してしまう現象である。

この解決策の一つとして、垂直統合があげられる。サプライ・チェーンの上流から下流までを統合することで全体の利益を最大にする戦略である。実際に垂直統合を行うハードルは高いものの、ザラ、ユニクロ、トヨタ自動車などは、これを行うことでサプライ・チェーンのダブル・マージナリゼーション解消に取り組んでいる。

2.3 クローズド・ループ・サプライ・チェーン

2.3.1 はじめに

前節で述べたようにサプライ・チェーン・マネジメントを取り入れている企業は年々増加し、サプライ・チェーン・マネジメントは企業にとって必要不可欠なものになってきている。さらに、このサプライ・チェーン・マネジメントは商業的なものだけではなく、人道支援の場面においても行われている。このように様々な場面で活用されるサプライ・チェーン・マネジメントの概念であるが、多くの企業がサプライ・チェーンを行うと、今後さらなる競争の激化が予想される。一方で企業は廃棄物等の問題をはじめとする地球環境への配慮が求められている。そこで企業の社会的使命を果たし、さらに差別化を図るべく、クローズド・ループ・サプライ・チェーンを推奨する。

本節では、はじめに循環型社会について説明する。そのごクローズド・ループ・サプライ・チェーンの概要、現状、課題について述べる。そして、クローズド・ループ・サプライ・チェーンのサブシステムのひとつであるリマニュファクチャリングについても述べる。

2.3.2 循環型社会

近年、二酸化炭素による地球温暖化問題、原油価格の上昇とピークオイル論が引き金となった原油枯渇説、レアメタルに代表される希少資源問題など、「有限の地球観」が必要とされる事象が顕在化してきている。このような問題を抱えながら世界全体が、20世紀後半の先進諸国の成長を続けていくことは不可能に近いと考えられる。そのため、今後の成長は、従来型の生産・消費・廃棄を繰り返すのではなく、持続可能性を担保したうえで成り立つと考えられる。

現在、環境問題に対する意識は高まっている。その背景には地球温暖化や、それに伴う異常気象、また消費活動の結果として排出される産業廃棄物の環境への悪影響がある。産業革命や高度経済成長期においては、環境問題への意識が低く、大量生産・大量消費・大量廃棄が行われた。その結果、廃棄物による大気汚染や水質汚染、生産過程において排出される二酸化炭素等の温室効果ガスによる地球温暖化が大きな問題となった。これにより環境問題への意識が徐々に高まっていった。

このような問題を解決するために、社会の構造を根本的に変えることが必要であった。自然界から採取する資源をできるだけ少なくし、それをリサイクル等によって有効に使うことによって、廃棄されるものを最小限におさえる社会へと転換しようと打ち出されたのが「循環型社会」である。日本では、2001年に循環型社会実現に向けて、循環型社会形成推進基本法が施行された。これは、これまでの「大量生産・大量消費・大量廃棄」型の経済社会から脱却し、環境への負荷が少ない「循環型社会」の形成を推進するとともに、循環型社会の形成について、基本原則を定め、並びに国、地方公共団体、事業者及び国民の責務を明らかにし、現在及び将来の国民の健康で文化的な生活の確保を

目的とした法律である。循環的な利用が行われる物品と処分が行われる物品を「廃棄物等」とし、廃棄物等のうち有用なものを「循環資源」と位置づけ、その循環的な利用を促している。この法律では処理の優先順位が初めて法定化され、その優先順位は(1)発生抑制、(2)再使用、(3)再生利用、(4)熱回収、(5)適正処分となっている。さらには、資源の有効な利用の促進に関する法律（資源有効活利用促進法）、特定家庭用機器の再商品化に関する法律（家電リサイクル法）、使用済自動車の再資源化等に関する法律（自動車リサイクル法）、使用済小型電子機器等の再資源化の促進に関する法律（小型家電リサイクル法）などが成立・施行されるようになり、日本社会の循環型社会への変遷がうかがえるようになった[13]。

循環型社会形成推進基本法には、拡大生産者責任（Extended Producer Responsibility：EPR）という考え方が取り入れられ、これは経済協力開発機構(OECD)加盟国政府に対するガイダンス・マニュアルに策定されている。この考えは、生産者に製品のライフサイクルにおける責任を課すことで、製品から発生する環境負荷の低減を目指す戦略である[13]。具体的には、製品設計の工夫、製品の材質・成分表示、一定製品について廃棄等の後に生産者が引き取りやリサイクルを実施することなどが含まれ、企業・メーカーは自社の事業を、自然と共生できる社会や持続可能な社会の構築といった社会的課題の解決に導くことが強く望まれている。

こういった環境への意識は徐々に広がっていき、EU では 2003 年に廃電気・電子機器の削減・再利用・リサイクルを目的とした WEEE 指令と、有害物質の使用を禁止とした RoHS 指令が執行され、環境対応が社会的に求められるようになった。

この持続可能な社会構築のための方策として、循環型生産システムが重要視されている。循環型生産システムは、廃棄される製品を回収して新しい製品の生産に活用するといったシステムであり、このシステムの確立が望まれている。次節ではその循環型生産システム確立に期待されるクローズド・ループ・サプライ・チェーンについてまとめる。

2.3.3 クローズド・ループ・サプライ・チェーン

これまで環境への配慮がなされないまま「大量生産・大量消費・大量廃棄」を行ってきた結果、資源枯渇問題や、廃棄物問題に直面している。また、生産から消費の過程で二酸化炭素等の排出により環境破壊や地球温暖化問題が引き起こされている。これらの問題に対処するために、循環型社会を構築することが求められている。

前節でも述べたが、ただ、サプライ・チェーン・マネジメントはあくまでサプライヤーから最終消費者に至る、サプライ・チェーン内での最適化であり、自社の製品を消費者が購入した以降についてのことは考慮されていない。つまり、モノを作りそれを売るという、あくまでも販売(サプライヤー)側の論理を最優先し、サプライヤーの利益のみを追求した経営戦略である。しかし環境問題に対処するには、消費者の使用後の製品に関しても企業側が考慮する必要がある。このような拡大生産者責任の概念の広まりによ

って製造企業は製品が耐久使用年数を迎えてから回収・リサイクルするまで責任を持つことが強く求められるようになり，消費者が使用した製品を回収し，メンテナンス，リマニュファクチャリング，部品リユース，材料リサイクルなどの循環型生産システムを構築し，環境負荷を低減させている．このようなシステムをクローズド・ループ・サプライ・チェーンと呼ぶ[14]．図 2.2 にクローズド・ループ・サプライ・チェーンの概略図を示す．

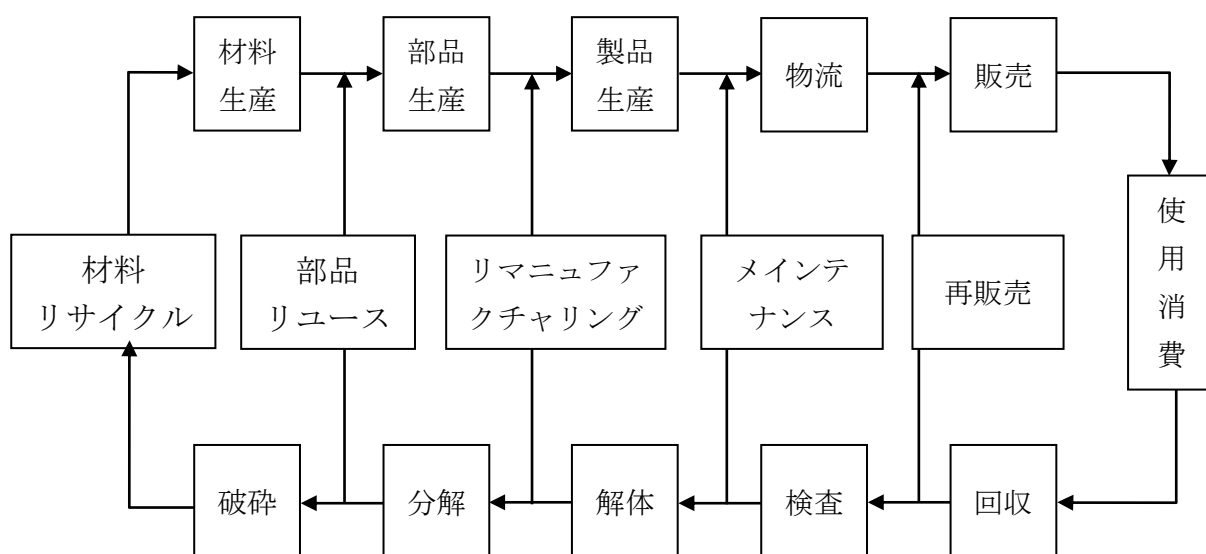


図 2.2 クローズド・ループ・サプライ・チェーンの概略図

※[14]を基に加筆・修正

2.3.4 クローズド・ループ・サプライ・チェーンの事例

現在，循環型社会の実現に向けて多くの企業がクローズド・ループ・サプライ・チェーンに取り組んでいる．しかし，実現は難しく課題があり実績を上げることが出来ないのが現状である．その中でも成功している事例として，富士ゼロックス株式会社とリコー株式会社について紹介する．

(1) 富士ゼロックス株式会社[15]

富士ゼロックスは，商品リサイクル全社方針「限りなく『廃棄ゼロ』を目指し，資源の再活用を推進する」を定め，環境負荷低減のために，企画・設計・調達から再資源化に至るまで，商品のライフサイクルすべての段階を視野に入れた取り組みを進めている．

富士ゼロックスでは，製品生産から販売，製品回収，再生産までの一貫したモノづくりの仕組みを，「資源循環システム」と呼んでおり，「使用済み商品は，廃棄物ではなく，貴重な資源である」という考えが基本になっている．このシステムは，使用済み製品を資源として有効利用する「クローズド・ループ・システム」を中心に，部品の再使用を前提に環境負荷の少ない製品作りを目指す「インバース・マニュファクチャリング（逆製造）」，再使用できない部品を分別・資源化し，再び新しい資源として活用する「ゼロエミッション」の三つで構成されている．

「インバース・マニュファクチャリング」は，ライフサイクル企画，リユース/リサイクル設計，環境影響アセスメント，クローズド・ループ・システムの四つのステップで構成されている．資源循環システムの根幹となる「クローズド・ループ・システム」は，部品のリユースを最優先にしている．さらに，環境アセスメントを実施し，環境に負荷を与えないような商品作りを目指している．このようにな，廃棄ゼロ化に向けた活動が「ゼロエミッション」である．

富士ゼロックスは業界で初めて，新品と同等の品質でリサイクルプラスチック素材を提供できる技術を素材メーカーと共同開発した．その資源循環システムは，一度使った資源を活かして，できる限り新たな資源は使わずに，廃棄ゼロを実現するものである．そうして作られたリユース部品を使った商品は，中古機として売り出さず新品同様のメーカー保証をしていることも特徴である．

(2) 株式会社リコー[16]

リコーは，人間社会が与える環境負荷が帰休環境の再生能力の範囲内に抑えられている社会にするため，「Three Ps Balance」として環境(Planet)・社会(People)・経済(Profit)の調和に配慮しながら，企業の社会的責任を果たし，社会からの信頼を得ること目指している．

資源・エネルギー消費量の低減，最終廃棄物の低減，有害物の排出防止を目的として，これらを達成するための再生産サイクルの概念をエネルギー・原材料から製品に至るま

での各段階のリサイクルを示した循環型社会の概念図として、「コメットサークル」を提案している。これを図 2.5 に示す。

この概念に基づき、環境保全と経済性を追求する経営を同軸のものとして企業活動を行っている。ごみゼロを全社目標とし、産業廃棄物、一般廃棄物だけでなく、生活系廃棄物までをゼロにし、資源の完全循環を目指している。製品のリユースや部品のリユースを優先的に行うことで使用済み製品の経済価値を高い状態に戻し、部品としてリユースできないものは材料リサイクルに回すとしている。その場合も高品質な素材へのリサイクルや再び使う資源へ戻すリサイクルを進め、コメントサークルによる高い経済価値の創出と新たな資源の投入や廃棄物の発生を抑制している。

リコーは、富士ゼロックスが再生機を新品同様に販売しているのに対して、リユース部品を使った商品は中古機（リコンディショニング：RC 機）として売り出している。リユース部品を使用しながら、新製品と同等の品質検査をクリアしている。

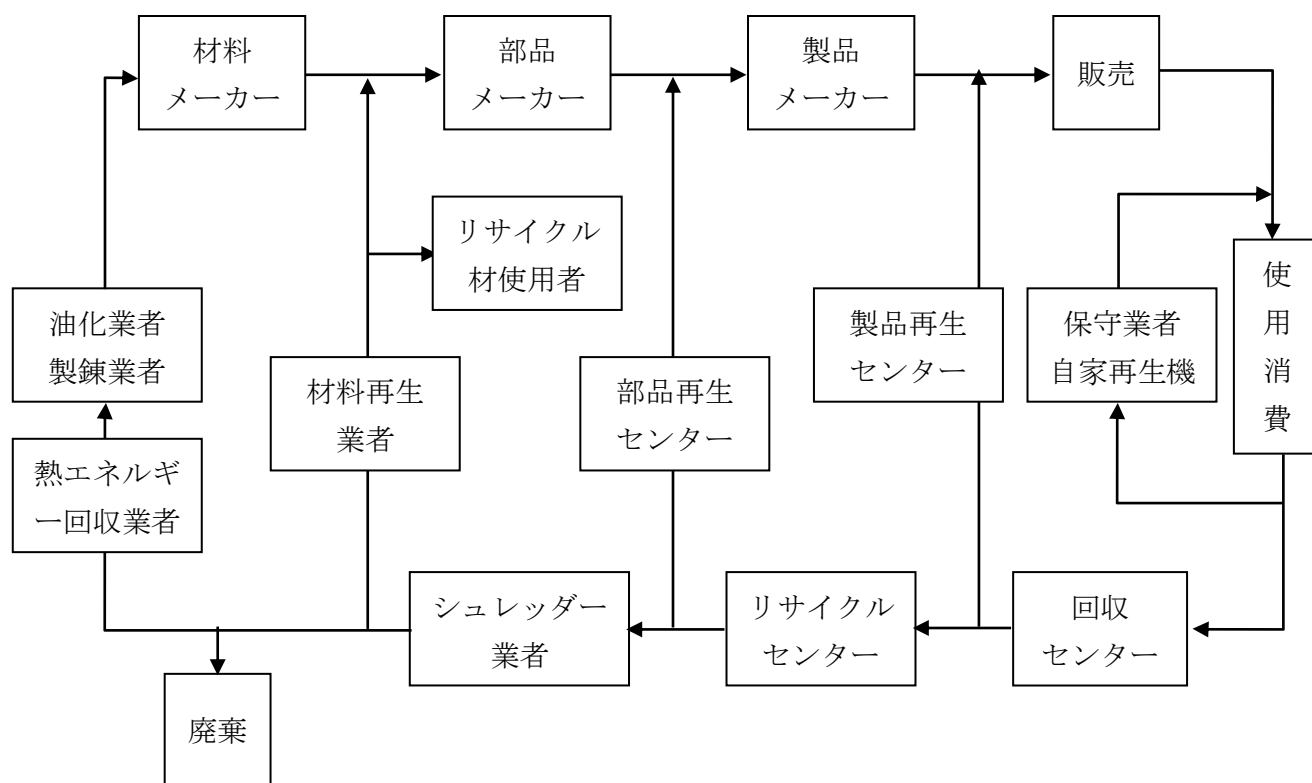


図 2.3 リコーコメントサークル概略図

※[16]を基に加筆・修正

2.3.5 クローズド・ループ・サプライ・チェーン・マネジメントの課題

サプライ・チェーン・マネジメントを構築する際に多くの課題があったように、クローズド・ループ・サプライ・チェーン・マネジメントにもいくつか課題が存在する。ここでは、その中でも代表的なものについてまとめる[17]。

(1) 新製品と再製造製品との競合

多くの企業には再製造を行う潜在能力がある。しかし、その能力を持ちながら、再製造製品の販売を行わないケースがある。それは、企業にとって新製品販売の方が再製造製品販売よりも利益が大きいことや、再製造製品を販売することで起こる新製品市場への影響が原因としてあげられる。これはカニバリゼーション効果と呼ばれ、再製造製品市場が、新製品市場を侵食することによって引き起こされる。

(2) 製品の寿命・価値の陳腐化

クローズド・ループ・サプライ・チェーンにおいて、寿命が短い製品は一般的に再製造を行うことが難しい。また、時間の経過とともに価値がなくなっていく（価値の陳腐化が激しい）製品は、たとえ再製造を行ったとしても、消費者によって購入されない問題がある。

(3) 使用済み製品の回収

再製造を行うためには、消費者からの使用済み製品を安定的に回収することが前提にある。しかし、回収にかかる時間や回収コストがかかりすぎてしまうと、企業は再製造を行うことによる利益を出すことが困難になってしまう。したがって、いかによい回収システムを構築するかが企業にとって重要な鍵となる。また、その回収量を予測することができれば、再製造製品の生産管理をスムーズに行うことが可能になると考えられる。

(4) 消費者受容性

ここまでに挙げたクローズド・ループ・サプライ・チェーンの課題における例は企業側からの色合いが強いが、消費者側からの受容性も重要である。再製造製品は消費者から十分に認識されていない場合や信頼感、安心感を持たれていない場合がある。消費者が再製造製品を購入するかどうかは再製造需要にとっての決め手になるため、企業は広報活動や品質管理など消費者の受容性を高める努力が必要である。

また、消費者は製品に対して WTP(Willingness To Pay: 支払意思額)を持つ。WTP とは消費者が製品に支払う意思のある金額の最大値のことで、消費者は新製品、再製造製品それぞれに対して WTP をもつ。特に、再製造製品に対する WTP は消費者によって差があるため、企業は消費者の WTP を考慮した価格設定を行う必要がある。

2.4 おわりに

近年、多品種少量生産が進む現代においてサプライ・チェーン・マネジメントを取り入れる企業は増加している。本章では、サプライ・チェーン・マネジメントの概要、実際の企業の事例、およびサプライ・チェーン・マネジメントが抱える課題について述べた。さらに、循環型社会構築に期待されるクローズド・ループ・サプライ・チェーンの概要、事例、課題について述べた。サプライ・チェーン・マネジメントを困難にしている要因の中で、需要の不確実性というものは最も根本的な問題である。そのため、正確な需要予測を行うことは常に求められている。次章では、需要予測についてまとめ、特にニューラルネットワークを使った需要予測のアルゴリズムについて述べる。

第3章 需要予測

3.1 はじめに

製造業企業では、製品の在庫量や販売の機会損失を少なくすることを目的として需要予測を行う。それに基づいて生産計画・販売計画を立案するため、需要を正確に予測することが求められている。需要予測の精度が低いと、販売計画と販売実績との乖離が生じ、それが販売計画と生産計画の乖離へとつながる。生産が過剰になれば、過剰在庫を生み製品在庫、中間在庫の増加によるコストアップを招く。さらに、在庫が増加し滞留期間が長期化することによって、廃棄ロスの増加や、リードタイムの長期化による顧客満足度の低下を招く。反対に、生産が過少になると、在庫不足から機会損失による売り上げ低下や、急な生産計画の変更が発生することでコストがかかる。このように、予測精度の低さは、企業経営全体に影響を及ぼし、売上・利益の減少に関わる[18]。

一般的にその予測方法として、出荷量や販売量などの時系列データを用いて、統計的に分析する方法が用いられている。しかし、近年の消費の多様化により需要は大きく変動していて、市場動向の予測は困難になっている。そこで注目されているのが、機械学習(ニューラルネットワーク)を用いた需要予測である。

本章では、統計的な需要予測モデルについて概要を述べ、ニューラルネットワークを用いた予測モデルについて概要とアルゴリズムについて述べる。

3.2 統計的な需要予測モデル

需要予測には、過去のデータに頼りながら予測モデルを活用する定量的予測法と、論理構造の立場から需要量を推定していく判断予測法の二つに大きく分けられる。ここでは、過去のデータを用いて関数を当てはめていこうとする定量的予測法について詳しく記載する。定量的予測方法は、時系列モデルと回帰モデルに分類される。時系列モデルとは、時間経過とともに形成されるパターンのモデルを構築し、それを先に延ばすことによって将来を予測する方法である。これに対して、回帰モデルは時間以外の変数を使う予測方法である。

3.2.1 時系列モデル[18]

時系列モデルは、時系列で変化するパターンを参考にモデルを作成し、将来を予測する。過去のデータのみで作成できる時系列モデルは導入しやすいため、多くの企業で主流となっている。ここで、過去の需要データがない場合や、現在の需要が過去の需要に対して完全独立である場合には、時系列分析は成り立たない。そのため、時系列分析ではまず過去のデータを蓄積しておくことが求められる。

一般に時系列は、傾向変動、循環変動、季節変動、不規則変動の四つの時系列の要素

から成り立つと考えられている。この四つの変動を分離させ、それぞれの変動を分析するモデルと、予測する変数（自己指標）の階差値を過去の各時点における階差値で表示した関数を用いようとする自己回帰モデル（AR モデル）に分けられる。

傾向変動とは、予測する変数を長期的に見た時に、上昇傾向なのか下降傾向なのかを示すものである。これは変数の細かな変化を見るのではなく、大局的に見た傾向をとらえる際に見る変動である。傾向変動の分析方法として移動平均法が有名である。

循環変動とは、予測する変数がある周期性をもって現れる変化を示すものである。傾向変動とは違い、上昇と下降の変化が一緒に見られる。循環変動の分析方法としては、これログラム分析やピリオドグラム分析、スペクトル分析が活用されている。

季節変動(とは、季節ごとに繰り返し起こる変化を示すものである。1 年を周期とした変動パターンを見せる。予測する変数で 12 か月移動平均を行うことで、季節変動を取り除くことができる。季節変動の分析方法としては、米国の CENSUS 局法や日本の EPA 法などが有名である。

次に自己回帰モデル(*autoregressive[AR]model*)について述べる。自己回帰モデルとは、予測変数のある期の値が、純粋にランダムな変動と過去の値の影響による部分（自己指標の過去の各時点における階差値）の和で表されるモデルである。このモデルを変形させたもので、生産予測などの短期の予測を用いる際に用いられる指数平滑法がある。指数平滑法は直近の売れ行きや変化を重視する場合によく使用される。

また、上記の自己回帰モデルに MA モデルという過去の各時点における不規則な変動のウェイト付の累積を複合させた、ARMA モデル(*autoregressive moving average model*)がある。さらに時系列の各時点間の差をとることで定常時系列得て、ARMA モデルで表わす ARIMA モデルがある。

3.2.2 回帰モデル

回帰モデルは、ある目的関数について説明変数を使った式で表す回帰式を用いて、需要がどの程度になるかを推定・予測する。ここで目的関数について説明変数が 1 次元なら単回帰、2 次元以上ならば重回帰と呼ばれる。もっとも単純な方法は一般化線形モデルを用いる線形回帰である。そのパラメータを推定する方法として最小二乗法がある。これらの回帰分析は相関性を用いて予測を行うため、必ずしも因果関係があるとはいえない。そのため回帰モデルを構築する時は多重共線性や因果関係をしっかり分析する必要がある。

3.3 ニューラルネットワークによる需要予測モデル[19][20]

時系列モデルにおいては、需要量の変動を数学モデルで表し、そのモデルを表現するという方法が一般的である。その数学モデルとしてよく用いられるのが多項式モデルである。多項式モデルを用いる場合、モデルの次数をできる限り大きく取れば、観測デー

タに対する適合性はよくなり、過去のデータを精度良く再現しうるモデルを同定できる。しかし、たとえば自己回帰モデルによる予測においては、次数を大きくしても必ずしも精度が良くなるとは限らない。さらに不確定な将来の需要変動が同定されたモデルに従うという保証もない。

一方で、ニューラルネットワークはその入出力関係が規定されている場合、誤差逆伝搬学習により自らの内部状況を入出力関係に対して最適な状態に変化させることが可能である。ニューラルネットワークによるモデルは、入出力関係を与える関数形を特に意識することなく、結果としてその関数形を内部状態として構築できる特徴をもつ。しかし、それは複雑なモデルであるため構造を解釈することが困難であり、計算過程がブラックボックス化してしまうという特徴もある。ここで、ニューラルネットワークについての概要と学習・予測方法・問題点について述べる。

3.3.1 ニューラルネットワーク

ニューラルネットワーク(neural network)は、人工知能分野(機械学習)におけるアルゴリズムの一つである。人間の脳内にある神経細胞(ニューロン)とそのつながり、つまり神経回路網を人工ニューロンという数式的なモデルで表現したものである。ニューラルネットワークを設計するための一般的な機械学習の技術には、教師あり学習と教師なし学習がある。教師あり学習のニューラルネットワークは、データを学習用(学習データ)と評価用(テストデータ)に分ける必要があり、学習データにおいて入力に応じて望ましい出力を生成するように学習される。そして、学習されたモデルにテストデータを入力することで予測を行う。ここからは、教師あり学習の順伝搬型ニューラルネットワークについて述べる。

順伝搬型ニューラルネットワークは、ネットワーク自体にループする結合をもたず、入力から出力へ単一方向にのみ信号が伝搬するものをさす。図 3.1 に単純なニューラルネットワーク構造を示す。




図 3.1 ニューラルネットワーク構造

図 3.1 において、一つの円のことをユニットと呼び、入力ユニットで構成されている層を入力層、中間ユニットで構成されている層を中間層、出力ユニットで構成されている層を出力層という。ここで、中間層を 2 層以上（入力層と出力層を合わせて全体が 4 層以上）の構造を持つ場合をディープニューラルネットワークと呼び、これを用いた機械学習の手法を「ディープラーニング」、または「深層学習」と呼ぶ。

3.3.2 単純パーセプトロン

ここからは、ニューラルネットワークの基礎的なアルゴリズムについて述べる。単純な例として、出力ユニットが 2 つの入力ユニットから信号を受け取る場合（図 3.2）について考える。入力ユニットから受け取った信号が、ある閾値 θ を超えるかどうかで出力が決まるとき、その入力と出力の関係を式(3.1)で表す。重み w を適切な値にすることで、入力 x_1, x_2 に対応する出力 y が得られる。

$$y = \begin{cases} 1 & (w_1x_1 + w_2x_2 \geq \theta) \\ 0 & (w_1x_1 + w_2x_2 < \theta) \end{cases} \quad (3.1)$$

さらに入力を n 個に拡張した場合、

$$y = \begin{cases} 1 & (w_1x_1 + w_2x_2 + \dots + w_nx_n \geq \theta) \\ 0 & (w_1x_1 + w_2x_2 + \dots + w_nx_n < \theta) \end{cases} \quad (3.2)$$

となり、関数 $f(x)$ を考えると、

$$f(x) = \begin{cases} 1 & (x \geq 0) \\ 0 & (x < 0) \end{cases} \quad (3.3)$$

この時の出力 y は、

$$y = f(w_1x_1 + w_2x_2 + \dots + w_nx_n - \theta) \quad (3.4)$$

と書き直すことが出来る。この $f(x)$ をステップ関数と呼ぶ。さらに、式を統一するため、 $b = -\theta$ とおき、重み w と入力 x をベクトルの内積を用いて考えると最終的な出力は、以下の形でまとめることが出来る。

$$y = f(w^T x + b) \quad (3.5)$$

これが、ニューラルネットワークの出力の一般形である。ユニットの出力がこの形で表されるニューラルネットワークモデルのことをパーセプトロンと呼び、図 3.2 のように入力した値がすぐに出力に伝搬する一番単純な形をしたモデルのことを単純パーセプトロンと呼ぶ。またここで定義したベクトル w を重みベクトル、 b をバイアス、と呼ぶ。




図 3.2 単純パーセプトロン

3.3.2 ロジスティック回帰と確率的勾配降下法

単純パーセプトロンでは、ステップ関数を用いて出力値が 0 か 1 を判別したが、このままでは出力が 1 に近い 0 と 0 に近い 0 を同じ 0 に含んでしまう。そのために、出力値が 0 か 1 かではなく、0 から 1 の確率で判断することが必要になる。その確率を出力する関数の一つとして、式(3.6)で表されるシグモイド関数がある。

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.6)$$

ステップ関数の代わりにシグモイド関数を使ったモデルのことをロジスティック回帰と呼ぶ。また、ステップ関数やシグモイド関数のように、ユニットの線形結合後の非線形変換を行う関数のことを総称して活性化関数と呼ぶ。

ある入力 \mathbf{x} に対して、ユニットが 0 か 1 になる確率を C とすると、それぞれの確率は、

$$p(C = 1|\mathbf{x}) = \sigma(\mathbf{w}^T \mathbf{x} + b) \quad (3.7)$$

$$p(C = 0|\mathbf{x}) = 1 - p(C = 1|\mathbf{x}) \quad (3.8)$$

と表される。 C は 0 か 1 しか取りえないため、 $y = \sigma(\mathbf{w}^T \mathbf{x} + b)$ とすると、以下のようにまとめられる。

$$p(C = t|\mathbf{x}) = y^t(1 - y)^{1-t} \quad (3.9)$$

ただし、 $t \in \{0, 1\}$ である。これにより、 N 個の入力データ \mathbf{x}_n と出力 t_n が与えられたときの尤度関数は下式のようにあらわすことが出来る。

$$L(\mathbf{w}, b) = \prod_{n=1}^N y_n^{t_n} (1 - y_n)^{1-t_n} \quad (3.10)$$

この尤度関数を最大化するように y パラメータを調整できれば、ニューラルネットワークの学習がうまくできていることになる。このような問題を最適化問題と呼ぶ。

関数の最大・最小を考える場合、パラメータの偏微分(勾配)を求める。そのために式(3.10)の対数を取り、全体を和の形で表す。

$$\begin{aligned} E(\mathbf{w}, b) &= -\log L(\mathbf{w}, b) \\ &= -\sum_{n=1}^N \{t_n \log y_n + (1 - t_n) \log (1 - y_n)\} \end{aligned} \quad (3.11)$$

この式(3.11)で表される関数のことを交差エントロピー誤差関数と呼ぶ。一般的には、関数 E を誤差関数または損失関数と呼ぶ。ここで反復学習によりパラメータを逐次的に更新する代表的な手法として、次式で表される勾配降下法がある。

$$\mathbf{w}^{(k+1)} = \mathbf{w}^k - \eta \frac{\partial E(\mathbf{w}, \mathbf{b})}{\partial \mathbf{w}} \quad (3.12)$$

$$\mathbf{b}^{(k+1)} = \mathbf{b}^k - \eta \frac{\partial E(\mathbf{w}, \mathbf{b})}{\partial \mathbf{b}} \quad (3.13)$$

ここで、 $\eta(>0)$ は学習率と呼ばれるハイパーパラメータであり、モデルのパラメータの収束しやすさを調整する。一般的に 0.1 や 0.01 といった適当な値が用いられる。勾配降下法により学習は可能となるが、データ数 N が増大することで計算時間が莫大になる問題が生じる。これを解決するための手法が、確率的勾配降下法である。勾配降下法が全データ数の和を求めてからパラメータを更新するのに対し、確率的勾配降下法ではデータを 1 つずつランダムに選んでパラメータを更新する。

$$\mathbf{w}^{(k+1)} = \mathbf{w}^k - \eta(t_n - y_n)\mathbf{x}_n \quad (3.14)$$

$$b^{(k+1)} = b^k - \eta(t_n - y_n) \quad (3.15)$$

上式を N 個のデータに対して計算する。勾配降下法でパラメータを 1 回更新するのと同じ計算量でパラメータを N 回更新できるため、効率よく最適な買いを探索できる。しかし、 N 個のデータに対して繰り返し学習する必要がある、この時の反復回数をエポックと呼ぶ。

3.3.3 多層パーセプトロンと誤差逆伝搬法

ここからは、図 3.1 に示しているような、入力層、中間層、出力層という 3 層のニューラルネットワークにおいて述べる。図 3.3 に 3 層のニューラルネットワークモデルを示す。まず、入力層から中間層の部分に着目すると、出力を表す式は、重み \mathbf{W} 、バイアス \mathbf{b} 、活性化関数 $f(\cdot)$ に対し、以下ようになる。

$$\mathbf{h} = f(\mathbf{W}\mathbf{x} + \mathbf{b}) \quad (3.16)$$

ここから得られた \mathbf{h} が出力層に伝搬するので、中間層から出力層では、重み \mathbf{V} 、バイアス \mathbf{c} 、活性化関数 $g(\cdot)$ に対し、以下ようになる。

$$\mathbf{y} = g(\mathbf{V}\mathbf{h} + \mathbf{c}) \quad (3.17)$$




図 3.3 多層パーセプトロン

多層になった場合のニューラルネットワークの学習（最適化）について，最小化すべき誤差関数を E とすると， $E=E(W,V,b,c)$ となる．これについて各パラメータに対する勾配を求める必要がある．これまで同様 N 個のデータがある場合， N 個それぞれのデータで発生する誤差 E_n に対する各パラメータの勾配を考える．まず，各層の活性化前の値をそれぞれ，

$$p = Wx + b \quad (3.18)$$

$$q = Vh + c \quad (3.19)$$

とおくと， $W=(w_1 w_2 \cdots w_J)^T$ 及び， $V=(v_1 v_2 \cdots v_K)^T$ に対して，

$$\begin{cases} \frac{\partial E_n}{\partial w_j} = \frac{\partial E_n}{\partial p_j} \frac{\partial p_j}{\partial w_j} = \frac{\partial E_n}{\partial p_j} x \\ \frac{\partial E_n}{\partial b_j} = \frac{\partial E_n}{\partial p_j} \frac{\partial p_j}{\partial b_j} = \frac{\partial E_n}{\partial p_j} \end{cases} \quad (3.20)$$

$$\begin{cases} \frac{\partial E_n}{\partial v_k} = \frac{\partial E_n}{\partial q_k} \frac{\partial q_k}{\partial v_k} = \frac{\partial E_n}{\partial q_k} h \\ \frac{\partial E_n}{\partial c_k} = \frac{\partial E_n}{\partial q_k} \frac{\partial q_k}{\partial c_k} = \frac{\partial E_n}{\partial q_k} \end{cases} \quad (3.21)$$

となり， $(\partial E_n)/(\partial p_j)$ および $(\partial E_n)/(\partial q_k)$ を求めれば，各パラメータの勾配が求められる．さらに，ここで，

$$\delta_j = \frac{\partial E_n}{\partial p_j} \quad (3.22)$$

$$\delta_k = \frac{\partial E_n}{\partial q_k} \quad (3.23)$$

とおくと，式(3.23)はモデルの出力と正解値の純粋な誤差を表しているため，これらのことを誤差と呼ぶ，誤差項を定義すると以下ようになる．

$$\delta_j = f'(p_j) \sum_{k=1}^K v_{kj} \delta_k \quad (3.24)$$

モデルの出力を考える際は、入力層から出力層への純向きで見てきたが、勾配を考える際はネットワークを逆向きで見ることで、誤差が伝搬していると捉えることが出来る。このように、ネットワークが多層になった場合のアプローチは、勾配を計算するための誤差が逆向きの出力を考えていくことで求められる。これを誤差逆伝搬法と呼び、すべてのディープラーニング(深いニューラルネットワーク)のモデルにおいて必要になる。

3.3.4 学習の問題と効率化

(1) 勾配消失問題

ニューラルネットワークモデルにおいて、単純に中間層の数を増やすだけでは学習はうまくいかない。その原因の一つとして勾配消失問題が挙げられる。モデルの学習では、最適解を求めるために各パラメータの勾配を求める必要があるが、この勾配が消えてしまう(=0になってしまう)問題が発生する。この問題の解決策として、活性化関数の選択や重みの初期値設定をするなどが挙げられる。

(2) オーバーフィッティング問題

ニューラルネットワークの教師あり学習において学習データに適合しすぎてしまい、学習データでの正解率(精度)が高いのに対し、テストデータでは正解率が低くなってしまう現象である。つまり、学習データだけに最適化されてしまい汎化性がないモデルといえる。これは、過学習あるいは過剰適合とも呼ばれる。

ニューラルネットワークにおいて、この過学習が大きな問題となる。中間層のユニットや層数を増やすことでより複雑なモデルを表現できるようになるが、モデルの学習において、誤差関数 E を最小化するようにパラメータを更新するが、単純に E を最小化することで過学習が起きてしまう可能性があるため、必ずしも E を最小化すればよいわけではない。過学習を抑制するためには、学習データを増やす、モデルを簡単なものにする、正則化を行うなどが挙げられる。

(3) ドロップアウト

ニューラルネットワークにおける学習の効率化の手法のひとつを紹介する。過学習を抑制し、モデルの汎化性能を向上させるシンプルな方法として、ドロップアウトという手法がある。これは、ニューラルネットワークを学習する際に、ある更新で層の中のユニットのうちのいくつかを無効にして学習を行い、次の更新では別のユニットを無効にして学習を行うことを繰り返す方法である。ドロップアウトを適用することで、学習時にネットワークの自由度を小さくし汎化性能を向上させている。ドロップアウト確率を

調整するパラメータ p は、その層のユニット数を固定して p 値を変化させるか、その層のユニット数を n としたときに $p \times n$ を一定値に固定して p と n を変化させる方法がある。

3.4 おわりに

本章では、消費の多様化による需要変動に対応するための需要予測方法について、これまでの統計的手法の概要と、ニューラルネットワークを用いた方法のアルゴリズムと学習の問題点について述べた。

次章では、本章で説明したニューラルネットワークを用いた予測方法により、需要予測モデルを提案する。

第4章 方法論

4.1 はじめに

(株) リコーでは市場に出回っているプリンターを回収、交換するだけでなく、プリンター内部の使用済み部品の回収、交換も行っている。概略を図 4.1 に示す。

本研究では、(株) リコーの実データをもとに、交換が行われる部品の交換（回収）予測を行う。予測方法をその後の生産計画に活かし、生産計画数及びそのタイミングの決定は収益管理上極めて重要な事項である[21]。部品の交換予測が可能ならば、それに伴う使用済み部品の回収予測や、部品の需要予測も可能となる。

今回、予測方法としてニューラルネットワークを用いた。予測対象となるプリンターが市場に存在する間のプリンター内部の部品交換台数予測方法を提案した。1 年間（12 か月）の交換台数実績値から次の 1 年を予測するモデルで、過去の部品交換実績値を用いて学習と予測を行う。

対象製品は 7 機種（A1, A2, A3, B1, B2, B3, M1）であり、全機種で使用されている一つの部品（部品 U）の実績交換データ使用する。対象機種の実データを表 4.1, 図 4.2 に示す。

ここで、各機種の関係について述べる。A 機種と B 機種においては、A1→A2→A3, B1→B2→B3 のように数字が上がるごとに新しい機種になっていくことを示し、同世代のアップグレードを示している。M1 機種は、A 機種と B 機種を足し合わせた次世代の最新機種である。




図 4.1 (株) リコーにおけるプリンターの交換

表 4.1 提案方法に用いるデータ

※（株）リコー実交換データ

プリンター 機種名	発売開始 月	交換開始 月	データ終了 月	データ数
A1	2008/06	2009/10	2018/08	107
A2	2010/11	2010/12		93
A3	2012/02	2012/03		78
B1	2008/06	2009/10		107
B2	2010/11	2010/12		93
B3	2012/02	2012/02		79
M1	2013/06	2013/07		62




図 4.2 A 機種の実績交換台数

※（株）リコー実交換データ




図 4.3 B 機種の実績交換台数
※ (株) リコー実交換データ




図 4.4 M 機種の実績交換台数
※ (株) リコー実交換データ

4.2 提案手法

4.2.1 ニューラルネットワークモデル

本研究で使用するニューラルネットワークモデルを図 4.4 に示す。12 期分（12 か月分）の実績値を入力することで、翌 12 期の交換数が出力されるモデルである（入力が 1 期～12 期ならば、13 期～24 期が出力となる）。

このモデルは、ニューラルネットワークの教師あり学習に該当する。そこで、データを学習データとテストデータに分ける必要がある。ここでは、A 機種 of 最新機種 A3 と B 機種 of 最新機種 B3、さらに A 機種と B 機種 of 次世代 of 最新機種 M1 をテストデータ（予測対象）とする。各テストデータにおける学習データは、同世代（A3, B3）の機種においては同世代の過去機種のデータを使用し、次世代（M1）の機種においては、相関係数により関連性の高いデータを選定して使用することとする。

また、このモデルの出力層のユニット数は 12 で固定するが、入力ユニット数と中間層の層数とユニット数においては、変化させて適切な値を決定する。入力要素は、部品交換データ以外に、交換された月、交換開始から何期目か、といった季節性やトレンド性が関係する要素や、MIF 値（Machine in Field 市場の稼働台数）や ADV（ある期間の平均印刷枚数）、製品・部品寿命値などといった部品交換数との関係性が強い要素が挙げられる。これらの要素を図 4.5 に追加し、その都度中間層を適当に決定し予測精度を確認する。

このモデルの特徴として、一つの時系列を持ったデータで学習と予測を行う一般的な方法ではなく、複数の時系列を持ったデータを扱っていることが挙げられる。また、12 期分のデータから次 12 期を予測するプロセスも特徴的である。




図 4.5 ニューラルネットワークモデル

4.3 学習データの選定

前節で述べたように、同世代機種への予測には同世代の機種を学習で使用する（A3 機種の予測には、A1 と A2 機種のデータを用いる）。しかし、次世代機種（M1 機種）への予測には、どの機種が学習データとして適しているかわからない。ニューラルネットワークの性質上、すべての過去機種のデータを学習させることも可能だが、そうすることで入力が増えすぎて良い予測ができない可能性がある。そのため、学習データの選定する方法として相関係数を用いる。相関係数とは、正の分散を持つ確率変数 X 、 Y が与えられたとき共分散を σ_{XY} 、標準偏差を σ_X 、 σ_Y とおいたとき、

$$\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} \quad (4.1)$$

ρ を確率変数 X 、 Y の相関係数という。

同世代への予測の場合も相関係数を用いて学習データとして適しているか確認する。A3 機種に対して A1 機種と A2 機種、B3 機種に対して B1 機種と B2 機種、M1 機種に対して、全 A 機種と全 B 機種の相関係数を確認する。表 4.2 と表 4.3 に A 機種と B 機種で使用するデータを示す。この期間のデータを用いて各機種に対して相関係数を求める。

A 機種の相関を示した散布図を図 4.6、図 4.7 に、B 機種の相関を表した散布図を図 4.8、図 4.9 にそれぞれ示す。図 4.6 を例にすると、縦軸が A1 機種の部品交換数、横軸が A3 機種の部品交換数である。

表 4.2 A3 機種との相関係数を求めるために使用したデータ

機種名	発売日	交換期間	全データ数	相関に使用した期間	相関に使用したデータ数
A3	2012/02	2012/03~2018/08	78	2012/03~2018/08	78
A2	2010/11	2010/12~2018/08	93	2011/03~2017/08	78
A1	2008/06	2009/10~2018/08	107	2010/03~2016/08	78

表 4.3 B3 機種との相関係数を求めるために使用したデータ

機種名	発売日	交換期間	全データ数	相関に使用した期間	相関に使用したデータ数
B3	2012/02	2012/02~2018/08	79	2012/02~2018/08	79
B2	2010/11	2010/12~2018/08	93	2011/02~2017/08	79
B1	2008/06	2009/10~2018/08	107	2010/02~2016/08	79




図 4.6 A3 機種と A1 機種の間関図




図 4.7 A3 機種と A2 機種の間関図




図 4.8 B3 機種と B1 機種的相关図




図 4.9 B3 機種と B2 機種的相关図

表 4.4 各機種的相关系数

A 機種	A1	A2
A3	0.638	0.714
B 機種	B1	B2
B3	0.769	0.758

各機種の間関係係数を表 4.4 にまとめた。これにより、同世代の機種において相関が非常に高いという結果が得られた。そのため、同世代の過去機種の部品交換データを学習データとして採用することは妥当であるといえる。ニューラルネットワークモデルにおいて、A 機種はテストデータを A3 機種、学習データを A1、A2 機種とし、B 機種ではテストデータを B3 機種、学習データを B1、B2 機種とする。

次に次世代機種である M1 機種と A 機種、B 機種の相関関係を確認する。表 4.6 に M1 機種と相関を求めるために使用したデータをまとめる。

表 4.6 M1 機種との相関係数を求めるために使用したデータ

機種名	発売日	交換期間	全データ数	相関に使用した期間	相関に使用したデータ数
M1	2013/06	2013/07~2018/08	62	2013/07~2018/08	62
A3	2012/02	2012/03~2018/08	78	2012/07~2018/08	
A2	2010/11	2010/12~2018/08	93	2011/07~2017/08	
A1	2008/06	2009/10~2018/08	107	2010/07~2016/08	
B3	2012/02	2012/02~2018/08	79	2012/07~2018/08	
B2	2010/11	2010/12~2018/08	93	2011/07~2017/08	
B1	2008/06	2009/10~2018/08	107	2010/07~2016/08	




図 4.10 M1 機種と A1 機種の相関図




図 4.11 M1 機種と A2 機種的相关図




図 4.12 M1 機種と A3 機種的相关図




図 4.13 M1 機種と B1 機種の相関図




図 4.14 M1 機種と B2 機種の相関図




図 4.15 M1 機種と B3 機種の相関図

表 4.5 M1 機種に対する各機種の相関係数

	A1	A2	A3	B1	B2	B3
M1	0.133	0.690	0.644	0.260	0.584	0.014

M1 機種と A 機種との相関図を図 4.10 から図 4.12 に、B 機種との相関図を図 4.13 から図 4.15 にそれぞれ示す。表 4.5 に M1 機種に対する各機種の相関係数をまとめる。この結果から、M1 機種は A2 機種、A3 機種、B2 機種と相関が高いことが分かった。M1 機種と A3、B3 機種が、発売日が一番近く最新機種であることから相関が高くなると予想したが、その傾向はみられなかった。M1 機種と他機種を比較すると、交換できる部品数や製品性能が違うため、各機種の相関係数にばらつきがでたと考える。

ニューラルネットワークモデルにおいて、M1 機種のテストデータを M1 機種、学習データを A2、A3、B2 機種として学習と予測を行う。

4.4 入力ユニット数と中間ユニット数の決定

前節で述べたように，入力要素には，部品交換数の実績値以外にも，部品交換された月，交換開始から何期目か，といった季節性やトレンド性が関係する要素や，MIF 値（Machine in Field 市場の稼働台数）や ADV(ある期間の平均印刷枚数)，製品・部品寿命値などといった部品交換数との関係性が強いと思われる要素が挙げられる．ここでは，部品交換データを入力要素とした 12 入力モデル（図 4.5）と，入力要素に交換された月と交換開始から何期目かの要素を追加した 14 入力モデル（図 4.16）と，それに MIF 値と ADV，部品寿命を追加した 17 入力モデル（図 4.17）の 3 つのモデルにおいて，その予測精度を比較する．さらに各モデルで中間層のユニット数を 10 から 30 まで変化させて RMSE を比較する．

予測値の評価指標として，予測値と実測値の比率(平均と標準偏差)と平均平方二乗誤差 (RMSE)を使用する．ここで P は予測値， O は実測値， i は各期数， N は全データ数である．

$$\overline{P/O} = \frac{1}{N} \sum_{i=1}^N \left(\frac{P_i}{O_i} \right) \quad (4.2)$$

$$s.d.(P/O) = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{P_i}{O_i} - \overline{P/O} \right)^2} \quad (4.3)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (4.4)$$




図 4.16 14 入力ニューラルネットワークモデル




図 4.17 17 入力ニューラルネットワークモデル

ニューラルネットワークモデルのパラメータを記す

使用言語：Python

実行環境：Anaconda3, Jupyter Notebook

ライブラリ：Keras

活性化関数：tanh

最適化アルゴリズム：Adam(学習率 0.001)

損失関数：平均二乗誤差

学習回数（エポック数）：1000 回

バッチサイズ：32

上記の設定でニューラルネットワークを作成，学習させる．プログラムの大まかな流れを図 4.18 に示す．ここでは，相関係数が高い B 機種 of データを使用し，予測対象を B3 機種，学習対象を B1, B2 機種とする．入力ユニット数を 12, 14, 17 の 3 パターンで，中間ユニット数を 10 から 2 ずつ 30 までの 11 パターンの変化をさせる．さらに中間層においてドロップアウトを導入して，その割合を 0.3, 0.2, 0.1 の 3 パターンとする．よって，99 パターンの RMSE を比較する．

その結果を，以下の表 4.6～表 4.8 に示す．赤字で記している数値が，その表の各入力における RMSE 最小値である．まず，入力ユニット 17 では他の入力と比べて RMSE が倍以上の数値になった．これは，入力要素として追加した「ADV」，「部品寿命」，「t 期の MIF 値」が予測精度を低下させていると考えられる．特に「ADV」と「部品寿命」は，時系列を持たない部品別の定数項であるため，その値のまま 1 ユニットとして入力している方法に問題があると考えられる．

入力 14 と 12 においては，全体的に似たような RMSE 値であることがわかる．また，ドロップアウトの割合が下がると，最適の中間ユニット数も小さくなる傾向がみられることから，中間ユニット数は 20 前後が適切ではないかと考える．中でも特にいい結果になったのが，ドロップアウト 0.1，入力ユニット数 14，中間ユニット数 22 の場合の RMSE=257.2 である．ここで，表 4.8 における中間ユニット 22 で入力 12, 14, 17 の場合の学習結果を図 4.20 と図 4.21，予測結果を図 4.22 に示す．入力の更新は 1 期ずつずらして計算を行っているが，図として表示しているのは 12 期（1 年分）ずつの結果である．例えば，1 期～12 期を入力すると 13 期～24 期を出力，13 期～24 期を入力すると 25 期～36 期を出力される．

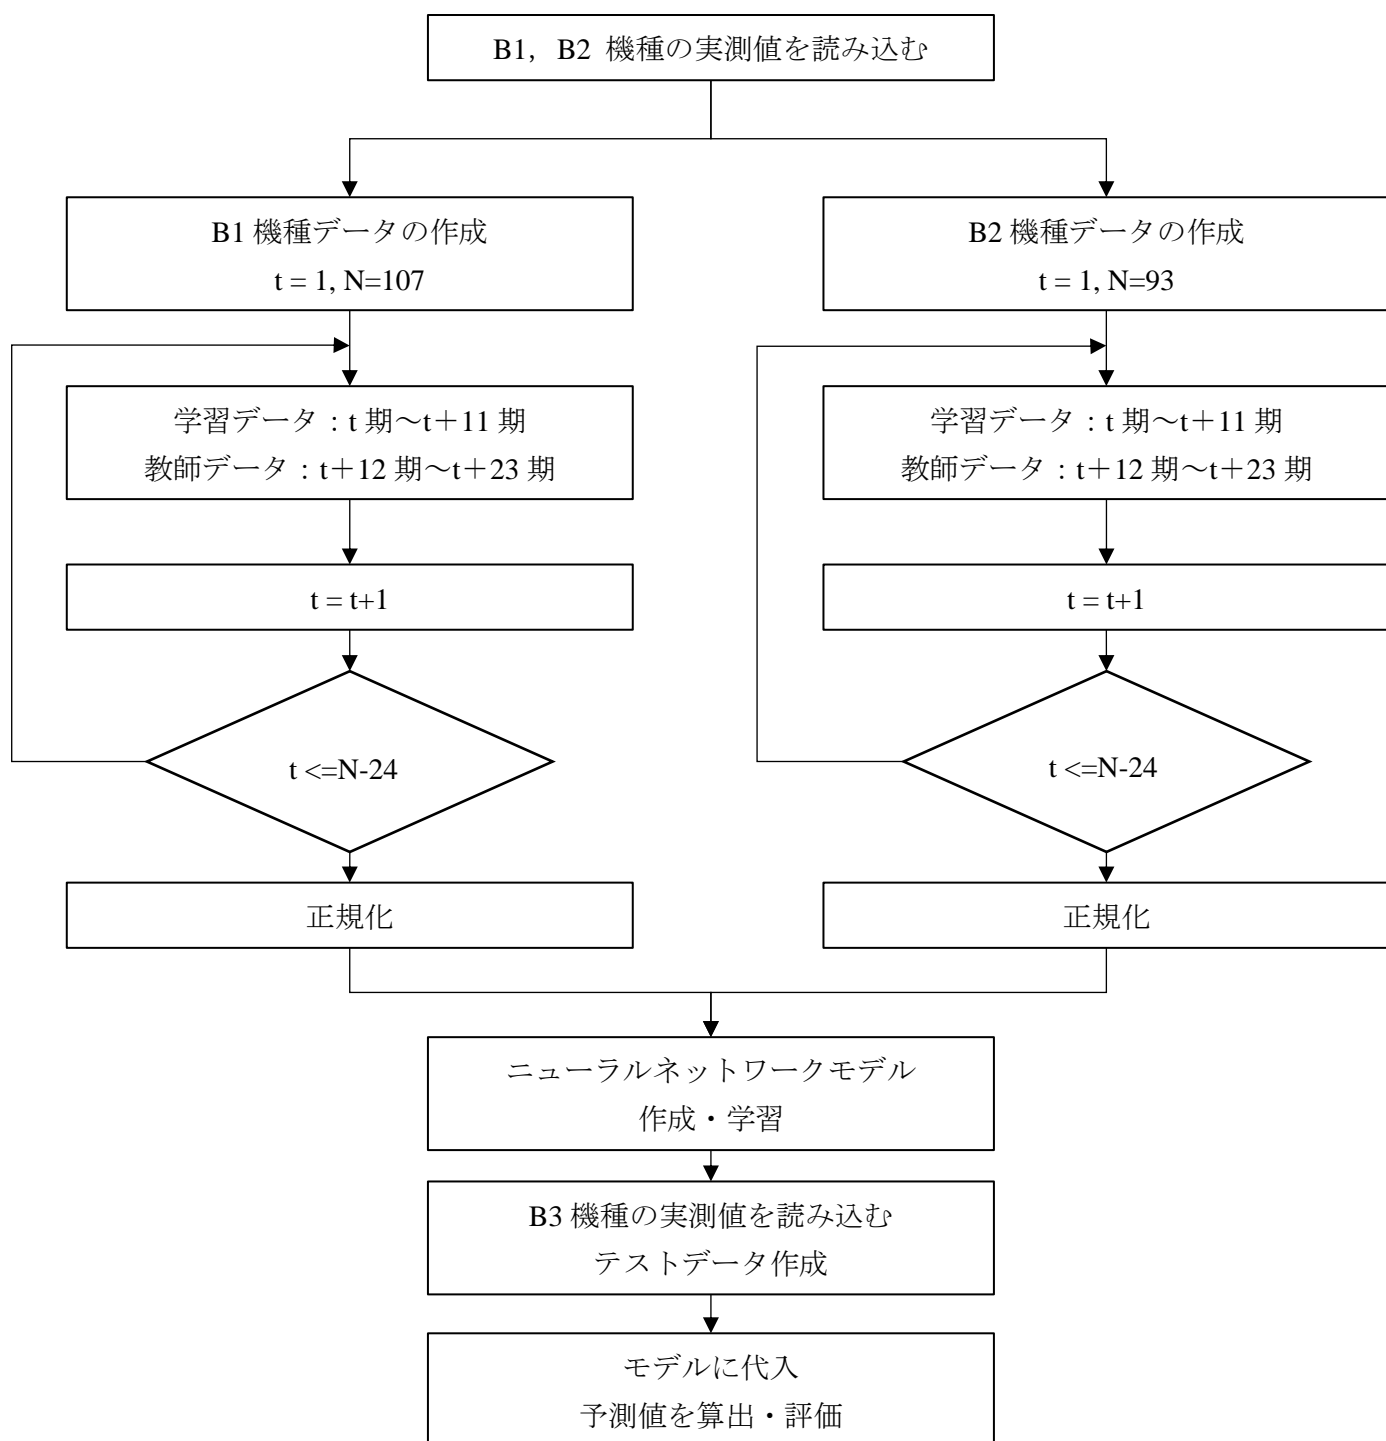


図 4.19 B3 機種を予測する際の流れ

表 4.6 RMSE 比較（ドロップアウト 0.3）

RMSE		中間ユニット数										
		10	12	14	16	18	20	22	24	26	28	30
入力ユニット	12	386.2	374	322.7	317.4	319.8	302.5	294.5	302.1	311.7	308.8	300.5
	14	376.5	372.5	374.5	361.1	357	343.1	308.5	311.4	302.3	288.2	304.4
	17	636.7	635.6	643.6	635.3	642	645.1	638.5	649.9	645.3	630.2	647

表 4.7 RMSE 比較（ドロップアウト 0.2）

RMSE		中間ユニット数										
		10	12	14	16	18	20	22	24	26	28	30
入力ユニット	12	325.6	308.2	309.8	301.2	294.4	290.4	300.3	284.7	290.1	299.7	274.8
	14	374.8	364.2	359.4	335	306	292.4	291.7	283.6	283.5	288.5	274.1
	17	637.9	640.6	644.6	650	641	646.4	645.7	653	670.7	684.9	694.4

表 4.8 RMSE 比較（ドロップアウト 0.1）

RMSE		中間ユニット数										
		10	12	14	16	18	20	22	24	26	28	30
入力ユニット	12	296.5	314.5	316.2	314.3	299.2	294.3	286.9	297.3	319.3	319.9	314.6
	14	354.1	324.7	289	296.6	270.8	283.4	257.2	258.7	284.7	277.5	268.6
	17	651.2	649.9	647.8	645.5	676.5	667.7	705.8	689.1	671.8	704.3	705.6




図 4.20 B1 機種の実測値と学習結果（ドロップアウト 0.1）




図 4.21 B2 機種の実測値と学習結果（ドロップアウト 0.1）




図 4.22 B3 機種の実測値と予測結果（ドロップアウト 0.1）

図 4.20 と図 4.21 の学習結果を見ると、どのモデルにおいても大きな学習の違いはないように見受けられる。図 4.20 では、14 入力と 17 入力モデルが 30～40 期にある上に凸の変化をよく捉えられている。それに対して 12 入力モデルは直線的な変化になっている。図 4.21 では、全モデルで似た学習結果になっている。これらの学習結果で得られたモデルに B3 機種のデータを入力すると図 4.22 になる。12, 17 入力モデルは直線的な予測が多くみられ、予測精度はよくない。対して 14 入力モデルは、予測値がなめらかな変化であり、実測値に対して当てはまりが良いことから、3 種類のモデルの中では精度の良いモデルであるといえる。

4.5 おわりに

本章では需要予測に用いる機種とデータ、ニューラルネットワークを用いた予測方法、入力ユニット数と中間ユニット数の適切な値などについて説明した。

次章ではこの結果を踏まえて、入力要素は 14、中間ユニットは 22 でドロップアウト 0.1 といったパラメータで A 機種と M1 機種においても予測を行う。そして 3 つの評価指標で考察を行う。

第5章 結果と考察

5.1 はじめに

本章では，前章までに述べてきた方法を用いて，A3 機種，B3 機種，M1 機種を対象に，実績値が少ない（12 期）期間から需要予測を行う．そして，得られた予測値と実測値の予測誤差を，予測値と実測値の比率と RMSE を用いて算出し，今回のニューラルネットワークモデルを用いた予測の精度を評価する．

5.2 学習データとテストデータ

4.2.2 節で相関係数を使って学習データを選定した．その結果を以下の表にまとめる．A 機種では，テストデータ（予測対象）を A3 機種，学習データを A2，A1 機種とする．B 機種では，テストデータを B3 機種，学習データを B2，B1 機種とする．M 機種では，テストデータを M1 機種，学習データを A3，A2，B2 機種とする．

また，ニューラルネットワークモデルは 14 入力モデルとし， t 期～ $t+11$ 期の部品交換数 12 ユニット， t 期の交換月 1 ユニット，交換開始から t 期目 1 ユニットの合計 14 ユニットを入力とする．出力は $t+12$ 期～ $t+23$ 期の 12 ユニットである．中間層に関しては，3 層とし，ユニット数は 18～22 まで 2 ずつ変化させて結果を表示する．

表 5.1 学習データとテストデータ

	A 機種	B 機種	M 機種
テストデータ	A3	B3	M1
学習データ	A2	B2	A3
	A1	B1	A2
			B2

5.3 評価指標

本研究では，提案方法による需要予測精度を評価する方法として，予測値と実測値の比率の平均(Ave(P/O))と，比率の標準偏差(s.d(P/O))，平均平方二乗誤差(RMSE)の 3 種類を用いる．Ave(P/O)で予測値と実測値の誤差の平均が算出され，この誤差が±10%以内であれば，（株）リコーで実際に使用できるレベルであると判断する．また RMSE は数値予測問題における精度評価指標の一つで，予測値が実績値からどれだけの誤差があるのかを示す．RMSE の値が 0 に近いほど予測精度は高いと評価することができる．

$$\overline{P/O} = \frac{1}{N} \sum_{i=1}^N \left(\frac{P_i}{O_i} \right) \quad (5.1)$$

$$s.d.(P/O) = \sqrt{\frac{1}{N} \sum_{i=1}^N \left(\frac{P_i}{O_i} - \bar{P} \right)^2} \quad (5.2)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (P_i - O_i)^2} \quad (5.3)$$

5.4 提案方法の結果

本研究では、(株) リコー製品の実データ(表 4.1)を基に分析を行った。7 機種における同部品 (1 種類) の実績交換データを用いて、学習データとテストデータに分けて、予測を行った。提案方法では、ニューラルネットワークモデルを用いて、初めに学習データを学習させて、その学習されたモデルにテストデータを入力し予測を行う。提案方法の精度を評価するために、予測値と実測値の比率の平均 (Ave(P/O))、比率の標準偏差 (s.d(P/O))、平均平方二乗誤差 (RMSE) を使って比較する。その評価指標を表 5.2 から表 5.4 に示し、各表において RMSE が最小であった結果を赤字で示す。この結果から RMSE が一番小さい結果の学習結果と予測結果を図 5.1 から図 5.11 に示す。このモデルでは、図 4.19 に記す通り 1 期ずつ入力と出力をずらして学習や予測を行っている。結果としては全期間を N 期とした際、入力が t 期～t+11 期から N-23 期～N-12 期まで、それに対応する出力が t+12 期～t+23 期から N-11 期～N 期まで取得できる。しかし、この出力をすべて表示すると見づらく評価できないため、結果の図においては 12 期ずつの結果をつなげて表示する。

各機種のテストデータにおける予測値と実測値の誤差を観察するために Ave(P/O)、s.d(P/O)、RMSE を算出する。

表 5.2 A3 機種における各中間ユニットの評価指標

		中間ユニット			
		18	20	22	24
A3 機種 評価指標	Ave(P/O)	1.144	1.14	1.13	1.122
	s.d(P/O)	0.289	0.218	0.25	0.215
	RMSE	174.9	129.4	146.6	135.7

表 5.3 B3 機種における各中間ユニットの評価指標

		中間ユニット			
		18	20	22	24
B3 機種 評価指標	Ave(P/O)	1.031	1.032	1.038	1.025
	s.d(P/O)	0.191	0.182	0.162	0.166
	RMSE	271.8	256.8	225.3	237

表 5.4 M1 機種における各中間ユニットの評価指標

		中間ユニット			
		18	20	22	24
M1 機種 評価指標	Ave(P/O)	1.263	1.149	1.197	1.216
	s.d(P/O)	0.562	0.58	0.582	0.612
	RMSE	689.3	682.1	681.2	714.8




図 5.1 A3 機種 of 予測における A1 機種 of 実測値と学習値




図 5.2 A3 機種 of 予測における A2 機種 of 実測値と学習値




図 5.3 A3 機種の実測値と予測値




図 5.4 B3 機種 of 予測における B1 機種の実測値と学習値




図 5.5 B3 機種 of 予測における B2 機種 of 実測値と学習値




図 5.7 B3 機種 of 実測値と予測値




図 5.8 M1 機種 of 予測における A2 機種 of 実測値と学習値




図 5.9 M1 機種 of 予測における A3 機種 of 実測値と学習値




図 5.10 M1 機種 of 予測における B2 機種 of 実測値と学習値




図 5.11 M1 機種 of 実測値と予測結果

5.5 提案方法の考察

図 5.1 から図 5.11 と表 5.2 から表 5.4 より、ニューラルネットワークモデルによる提案手法は、同世代の機種予測においては精度が良い結果となり、次世代の機種予測においては精度良くない結果となった。一番良い結果だったのは B 機種で、その予測誤差は 3.8%、RMSE は 225.3 であった。ここで図 5.4 の学習結果をみると、予測値の当てはまりの悪さから、この機種における学習精度はよくないと判断できる、しかし、次の図 5.5 の学習結果ではあてはまりが良い結果である。この 2 機種を学習したモデルで予測を行うと図 5.6 の一番いい結果が得られた。このことから、同世代の機種においては、学習結果がすべていい結果である必要はないということがわかる。

それに対して、次世代の機種予測結果を示した図 5.11 では 13 期から 24 期と、48 期 から 60 期の予測が大きく外れている。この理由は明白であり、学習データとテストデータの変化が大きく離れているということである。図 5.8 から図 5.10 の学習結果の実測値を見ると 30 期から 40 期ピークが来て山なりの変化をしている。それに対して、図 5.11 の実測値を見ると 60 期まで右肩上がりの変化をしている。この原因として、機種の違いによるトレンド性や部品数、寿命などのパラメータが影響したのだと考えられる。このように、学習データとテストデータ大きく違うと予測することは難しい。また、第 4 章で述べた、学習データを選定する際の相関係数という方法に関して、次世代の機種のデータ数がある程度（50 期ほど）ないと過去機種との相関が取れないという問題点がある。

以上より、今回提案した、ニューラルネットワークモデルを用いた予測手法ではその入力要素において、機種による違いを判断する要素が弱い。同世代の機種において過去機種を学習することで高い精度の予測が可能であるが、次世代の機種（全く新しい機種）において予測をすることは困難であるといえる。

5.6 各入力モデルによる結果比較

上節までは入力ユニットを 14 として結果を比較したが、M1 機種において学習データとテストデータのトレンド変化が違ふことからうまく予測できなかった可能性があるため、各入力モデルを比較する必要があると考えた。そのため、4 章で行った入力ユニットと中間ユニットを変化させて精度の良いパターンを見つける作業を全機種で再度行い、一番精度が良かった入力モデルを機種ごとに比較する。表に各入力の評価指標をまとめ、その中で RMSE が最小の値を赤字で示し、それを図にグラフで表す。

表 5.5 12 入力モデルによる A3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.204	0.352	179.3
12	1.196	0.327	177.4
14	1.223	0.339	180.7
16	1.193	0.291	176.8
18	1.204	0.298	182.4
20	1.163	0.255	164.1
22	1.163	0.259	162.6
24	1.162	0.246	159.2
26	1.167	0.269	159.5
28	1.179	0.258	170.2
30	1.162	0.25	159.3

表 5.6 14 入力モデルによる A3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.174	0.32	149.9
12	1.17	0.311	154.4
14	1.172	0.312	164.6
16	1.152	0.239	132.8
18	1.155	0.238	141.9
20	1.128	0.232	138.8
22	1.157	0.241	137.9
24	1.117	0.258	147.4
26	1.126	0.217	137.4
28	1.121	0.219	131.6
30	1.135	0.232	157.6

表 5.7 17 入力モデルによる A3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.104	0.393	207.4
12	1.12	0.424	215
14	1.097	0.382	197.4
16	1.137	0.483	234.1
18	1.114	0.464	229.6
20	1.103	0.409	203.9
22	1.122	0.428	220.6
24	1.128	0.441	218.2
26	1.129	0.48	242.2
28	1.137	0.428	222.3
30	1.132	0.475	237.6




図 5.12 A3 機種における各入力結果比較

表 5.8 12 入力モデルによる B3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.071	0.231	338.4
12	1.073	0.233	339.4
14	1.064	0.233	345.5
16	1.051	0.216	320.3
18	1.038	0.202	311.5
20	1.02	0.205	323.9
22	1.037	0.202	315.1
24	1.014	0.18	291.8
26	0.9822	0.186	324.9
28	0.9848	0.178	308.2
30	0.9686	0.203	353.7

表 5.9 14 入力モデルによる B3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.046	0.285	346.4
12	1.043	0.2	269.3
14	1.049	0.185	241.4
16	1.043	0.184	249.9
18	1.037	0.189	253.5
20	1.05	0.165	222.5
22	1.024	0.17	239.3
24	1.007	0.181	270.3
26	1.014	0.186	268.1
28	1.024	0.181	277
30	1.016	0.169	259.8

表 5.10 17 入力モデルによる B3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.086	0.439	670
12	1.088	0.445	683.1
14	1.076	0.436	677.9
16	1.071	0.418	651.2
18	1.082	0.445	694.9
20	1.103	0.466	707
22	1.142	0.539	746.9
24	1.145	0.541	738.4
26	1.18	0.578	768
28	1.179	0.568	744.2
30	1.166	0.578	770.2




図 5.13 B3 機種における各入力結果比較

表 5.11 12 入力モデルによる M1 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.245	0.376	426.5
11	1.269	0.395	440.6
12	1.256	0.38	448.9
14	1.258	0.364	443.8
16	1.26	0.374	470.2
18	1.297	0.373	498.5
20	1.329	0.452	514.2
22	1.277	0.373	488.5
24	1.26	0.335	500.9
26	1.268	0.38	499.2
28	1.229	0.303	478.7
30	1.293	0.388	530.1

表 5.12 14 入力モデルによる M1 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	1.292	0.739	595.8
12	1.236	0.673	659
14	1.2	0.618	680.6
16	1.177	0.578	657.2
18	1.171	0.583	683.7
20	1.177	0.564	664.7
22	1.152	0.552	659.3
24	1.186	0.563	676.2
26	1.263	0.48	670.9
28	1.284	0.602	699.4
30	1.166	0.486	652.9

表 5.13 17 入力モデルによる B3 予測結果の評価指標

	aveP/O	sdP/O	RMSE
10	0.7742	0.718	1444
12	0.661	0.536	1483
14	0.6764	0.55	1464
16	0.6223	0.509	1508
18	0.6427	0.525	1489
20	0.6677	0.502	1401
22	0.6388	0.516	1486
24	0.6677	0.516	1428
26	0.6298	0.514	1506
28	0.818	0.631	1293
30	0.5687	0.444	1528




図 5.14 M1 機種における各入力結果比較

各入力と比較結果について考察を行う。まず全体の結果から、入力 17 のモデルの精度が良くない。その原因として、入力要素に追加している、「ADV」と「ユニット寿命」が定数項であることが考えられる。製品ごとのパラメータの違いを表す情報として追加したが、入力の与え方に問題がある可能性がある。A 機種における入力 17 の結果が誤差約 10 % であるが、RMSE とグラフを確認すると、予測値が実測値の上振れと下振れが平均されて誤差が小さくなっているため、よい精度とは言えない。

機種 A と B においては、入力 14 の結果が一番精度良い結果となった。これは、学習データに同世代機種を用いているため、トレンド性と季節性がテストデータに類似しており良い結果となったと考えられる。

機種 M においては、入力 12 の結果が良い結果となった。前節で考察したように、学習データとテストデータのトレンド変化が異なるため、部品交換数の変化のみを入力したほうが良いことがわかった。しかし、一番いい結果でも誤差 24.5 % であるため、まだ改善する必要がある。そこで、精度を向上させる方法として、学習データを増やすことが考えられる。下図は学習データに VE 機種を追加して予測を行ったものである。




図 学習データを追加した結果比較 (M1 予測)

表 評価指標

	aveP/O	sdP/O	RMSE	中間ユニット数
12	1.245	0.376	426.5	10
VE 追加	1.211	0.264	393	30

学習データを1機種増やした結果、わずかだが精度が向上した。このようなトレンド性や季節性が全く予測できない次世代機種の予測に関しては、学習データ（機種数）を増やすことは予測精度向上につながる可能性がある。しかし、このモデルを用いて、過去の類似製品すべてを学習させることで精度が必ず良くなるわけではないため、テストデータに対する学習データの選び方がネックになると考えられる。

5.7 おわりに

本章では、提案したニューラルネットワークモデルにおいての評価を行い、考察として学習データとテストデータの重要性について述べた。

次章において、本研究の結論と今後の課題について述べる。

第6章 結論

近年、サプライ・チェーン・マネジメントと呼ばれる各種の方法論や事例について極めて大きな関心がもたれている。バブルの崩壊とともに、消費者のニーズが多用していたことで市場の成熟化が進み、企業は今までとは異なる新たな生産体系を構築することが求められている。その中でも、製造業では使用済みの製品を顧客が廃棄物として処分するのではなく、企業が再製造のために回収するという形で環境問題に取り組む例が増えてきている。このシステムを機能させるために重要になるのがクローズド・ループ・サプライ・チェーンである。このシステムの中の一つであるリマニュファクチャリングは、その資源消費や廃棄物の削減に大きな役割を果たすとされており、近年では主に複写機を取扱う製造業などで取り入れられている。本研究では、このリマニュファクチャリングに着目している。製品に組み込まれている部品は使用後、新しい部品と交換される。このとき重要なこととして部品の交換台数と交換時期があり、これらを予測することがその後の生産計画を立てるために必要不可欠である。これらの予測が大きく外れると、在庫過多や機会損失につながり企業の利益に直接影響を及ぼす。

本研究の目的は、部品交換回収予測にニューラルネットワークを用いて、過去機種の部品交換データを学習させることで、最新機種の部品交換データが少ないときの部品交換量の予測を可能にすることである。

提案手法では、学習データとテストデータの選定に相関係数を用いて行った。さらに入力ユニットと中間ユニットを変化させて複数のパターンで予測精度を確認した、それにより得られたモデルで学習と予測を行い、実測値と予測値の比率（平均と標準偏差）と RMSE によって評価を行う。

予測結果としては、同世代機種（A 機種、B 機種）においては予測精度が良い結果となり、過去機種を学習させることで、新機種の予測を実現することが出来た。しかし同機種の予測誤差に比べて、次世代機種（M1 機種）の予測誤差が大きくなってしまった。その要因のひとつとして、次世代機種において学習データとテストデータのトレンド変化が乖離していることが挙げられる。部品交換数の変化の違いとして、学習に使用した機種と予測に使用した機種とで製品自体の部品数や寿命などのパラメータが違うことも原因であると考えられる。また、次世代機種の学習データを選定する際に、相関係数を使用するために、ある程度データ数が必要になるといった課題点がある。

以上より、今回提案したニューラルネットワークモデルでは、同世代機種の新製品の予測には使える可能性があるが、全く新しい機種の予測には改善点が残るという結果になった。

謝辞

本研究を進めるに当たり、日頃より暖かいご指導を賜りました開沼泰隆先生に心より感謝の気持ちを申し上げます。開沼泰隆先生には、他大学からの入学を受け入れてくださり、本テーマを研究するにあたっての心構えや、取り組み方のご指導だけでなく、さまざまなことをご教授いただき、2年間大変お世話になりました。また、2年間共に切磋琢磨して研究を進め、研究室での生活を過ごさせて頂いた森川和哉さん、鈴木偉丸さん、樊静さん、張榮慧さんに感謝申し上げます。

研究室を支えて下さり、助け合って研究室生活を過ごさせて頂いた小川銀平さん、折田昂洋さん、TSHIVHASE,TSHIANEO TRACEY, THANYATORN PLOY, 桒知時さん、趙子鈺さん、山本遼太さん、岩上文佳さん、内野菜月さん、西村萌さん、内海柚香さん、梁小芸さんに感謝を申し上げます。

さらに、本研究の共同研究として回収部品のデータ提供にご協力下さるとともに、毎月報告会を開いて頂き、貴重なご意見を頂戴した株式会社リコー並びにリコーインダストリー株式会社の皆様に心より感謝致します。

参考文献

- [1] 徳山博子, 曹徳弼, 熊本和浩:「生産マネジメント」, 朝倉書店 (2002)
- [2] 中野幹久:「サプライチェーン・プロセスの運営と変革一部門間の調整とパフォーマンスの関係」, 白桃書房(2010)
- [3] 圓川隆夫:「オペレーションズ・マネジメントの基礎 - 現代の経営工学 - 」, 朝倉書店(2009)
- [4] 日本規格協会:「JIS ハンドブック 57 品質管理」, 一般財団法人日本規格協会 (2015)
- [5] CSCMP HP : <http://cscmp.org/> (2019 年 12 月 08 日)
- [6] 森田道也:「サプライチェーンの原理と経営」, 新成社(2004)
- [7] Mentzer, J. T., DeWitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C.D., Zacharia, Z.G.: “Definig supply chain management”, *Journal of Business Logistics*, Vol.22, No.2, pp.1-25 (2001)
- [8] 菊池康也:「実践 SCM サプライチェーンマネジメントの基礎知識」, 税務経理協会(2008)
- [9] 藤川裕晃:「サプライチェーン・マネジメントとロジスティクス管理入門」, 日刊工業新聞社 (2008)
- [10] Lee, H. L.: “The Triple-A Supply Chain” , *Harvard Business Review October* (2004)
- [11] 藤野直明:「サプライチェーン経営入門」, 日本経済新聞出版社(1999)
- [12] 松林伸生:“サプライチェーンにおける形態形成への協力ゲーム論的アプローチ”, オペレーション・リサーチ, Vol60, No5, pp.274-280 (2015)
- [13] 環境省 HP : <http://www.env.go.jp/> (2019 年 12 月 08 日)
- [14] 開沼泰隆:“クローズド・ループ・サプライ・チェーンにおけるリマニュファクチャリング”, 日本情報経営学会誌, Vol.32, No.4, pp.17-22(2012)
- [15] 富士ゼロックス株式会社 HP : <http://www.fujixerox.co.jp/> (2019 年 12 月 8 日)
- [16] 株式会社リコーHP : <http://www.ricoh.co.jp/> (2019 年 12 月 8 日)
- [17] 佐々木慶彦:“ハイブリッド製造／再製造システムにおける再製造品のカニバリゼーション効果に関する研究”, 平成 27 年度首都大学東京大学院修士論文 (2015)
- [18] 山下裕丈:“販売予測における課題の考察”, 産業経済研究所紀要, 第 19 号, pp.121-135 (2009)
- [19] 木村有寿, 有蘭育生, 太田宏:“ニューラルネットワークの需要予測への応用”, 日本経営工学会誌, Vol44, No5, pp.401-407(1993)
- [20] 巢籠悠輔:「詳解ディープラーニングーTensorFlow・Keras による時系列データ処理ー」, マイナビ出版(2017)

- [21] 田中謙司：“ライフサイクル累積販売数予測による生産計画数決定法の研究”，第
二回システム創成学学術講演会，pp.117-121 （2009）
- [22] 開沼泰隆，高橋健一，岡本真一，塩沢清茂：“大気質モデル性質の評価方法に関する
研究”，大気汚染学会誌，第 22 巻，第 6 号，pp.416-424 （1987）